

## Teorijski i metodološki pristupi kategorijalnom učenju

Valnea Žauhar

Odsjek za psihologiju, Filozofski fakultet Sveučilišta u Rijeci

---

### Sažetak

Na temelju brojnih istraživanja kojima se pokušalo utvrditi na koji se način usvaja znanje koje će biti reprezentirano unutar kategorija razvijeni su različiti pristupi kategorizaciji i kategorijalnom učenju. Ovaj rad predstavlja pregled pristupa kategorijalnom učenju počevši od dvadesetih godina prošlog stoljeća do danas. Prema pristupu definirajućih obilježja, kategorijalno je učenje proces nalaženja definicija ili pravila koja jednoznačno određuju pripadnost kategoriji. Teorija prototipa definira kategorijalno učenje kao proces stvaranja sumarnih reprezentacija ili apstrahiranja prototipa, odnosno, učenja najreprezentativnijega predstavnika koji odražava prosjek obilježja svih pripadnika kategorije. Teorija egzemplara promatra kategorijalno učenje kao pohranjivanje pojedinačnih egzemplara u dugoročno pamćenje sve dok kategorizacija ne dosegne optimalnu razinu točnosti. Navedenim teorijama suprotstavljen je integrativni pristup koji pretpostavlja da je kategorijalno učenje pod utjecajem šireg predznanja, koje se neizostavno aktivira prilikom nailaska na entitete koje je potrebno ispravno klasificirati. Na kraju, prikazana su najnovija istraživanja koja upućuju na to da kategorijalno učenje nije moguće objasniti jednim sustavom učenja već da je ono posredovano višestrukim, kvalitativno različitim, sustavima učenja i pamćenja. Posebna je pažnja posvećena razlici između eksplicitnog ili deklarativnog sustava i implicitnog ili proceduralnog sustava, a istraživanja pokazuju kako vrsta kategorije koju je potrebno usvojiti određuje koji će se od sustava aktivirati tijekom učenja.

**Ključne riječi:** kategorijalno učenje, definirajuća obilježja, prototipi, egzemplari, predznanje, višestruki sustavi kategorijalnog učenja

---

### Uvod

Objekte i situacije s kojima se svakodnevno susrećemo potrebno je smisleno organizirati i strukturirati s ciljem efikasnog funkcioniranja u okolini koja nas okružuje. Životno je važno znati reagirati na različite zahtjeve okoline, pa će tako,

---

✉ Valnea Žauhar, Odsjek za psihologiju, Filozofski fakultet Sveučilišta u Rijeci, Sveučilišna avenija 4, 51000 Rijeka. E-pošta: [vzauhar@ffri.hr](mailto:vzauhar@ffri.hr).

Ovaj je rad nastao u okviru znanstvenih projekata *Metacognition in Category Learning, Thinking and Comprehension (METCALTHIC, 4139)*, koji financira Hrvatska zaklada za znanost te *Kognitivni i neurodinamički aspekti percepcije, učenja i mišljenja (13.04.1.3.11)*, koji financira Sveučilište u Rijeci.

primjerice, sposobnost razlikovanja potencijalno opasnih od bezopasnih životinja odrediti hoćemo li nekoj životinji pristupiti, razlikovanje prijatelja od neprijatelja bit će ključno za ostvarivanje socijalnih interakcija, a razlikovanje jestivog od nejestivog bit će ključno za preživljavanje (Ashby i Maddox, 2005). Strukturiranje naučenog odvija se formiranjem pojmova ili mentalnih reprezentacija o kategorijama objekata. Pojmovi koje konstruiramo pomažu nam razumjeti i primjereno odgovoriti novom entitetu na kojeg nailazimo, povezuju naša prošla iskustva s našim sadašnjim interakcijama, a međusobno su povezani u šire strukture usvojenog znanja. Kada ne bismo imali sposobnost stvaranja pojmova, snalaženje u okolini bilo bi znatno teže: prilikom svakog susreta s entitetom s kojim se ranije nismo susreli, učenje bi moralo krenuti od samog početka (Murphy, 2002; Smith, 1993). Jedna od najčešće ispitivanih funkcija pojmova jest kategorizacija, odnosno, kognitivni proces grupiranja podražaja unutar kategorija ovisno o određenim svojstvima koje podražaje povezuju. Pri tome, kategorija je mentalna reprezentacija pohranjena u pamćenju u čijoj se podlozi nalaze složene relacije pripadnika kategorije, a pripadnost kategoriji određena je svojevrsnim pravilnostima koja mogu biti više ili manje očita. Kategorizacija pokreće širok spektar podređenih funkcija, a jednom kada se novi podražaj kategorizira, postojeće relevantno znanje moguće je koristiti za razumijevanje i predikciju. Povrh toga, kategorizacija novih podražaja služi modificiranju postojećih kategorija (Medin i Rips, 2005). Ljudi svakodnevno bez napora kategoriziraju objekte, događaje i situacije neovisno o tome što se u podlozi kategorizacije odvijaju kompleksni kognitivni procesi (Barsalou, 1992). Brojnim se istraživanjima pokušalo utvrditi na koji se način usvaja znanje koje će biti reprezentirano unutar kategorija, odnosno, ispitivalo kategorijalno učenje. Kategorijalno učenje definira se kao proces unutar kojeg sposobnost dodjeljivanja podražaja kategorijama od inicijalnoga slučajnog pogađanja doseže stabilnu razinu (Murphy, 2002), odnosno šire, kao proces unutar kojeg se kategorijalno znanje pohranjuje u pamćenju kako bi ga se posljedično moglo koristiti prilikom kategorizacije. Kategorizacija i kategorijalno učenje vrlo su istraživano područje u okviru kojega su razvijeni, a razvijaju se i dalje, teorije i modeli koji pokušavaju odgovoriti upravo na pitanje kako djeluje proces kategorijalnog učenja.

## **Klasične teorije kategorizacije i kategorijalnog učenja**

### *Pristup definirajućih obilježja*

Klasični pristup kategorizaciji i kategorijalnom učenju naziva se pristupom definirajućih obilježja (Smith i Medin, 1981). Prema pristupu definirajućih obilježja (Hull, 1920; Smoke, 1932), pojmovi su mentalno reprezentirani kao definicije pri čemu znanje o pojmu čini popis obilježja, poput definicija u rječniku, a definicija predviđa svojstva koja su pojedinačno nužna i zajednički dovoljna za

određivanje pripadnosti kategoriji. Kategorija je istovjetna definiciji ili pravilu koje se nalazi u podlozi kategorizacije, odnosno, određena je skupom svojstava koja predstavljaju temeljne jedinice značenja. Primjer definicije kategorije *PAS* može biti da se radi o *životinji* koja je *sisavac*, koja *ima četiri noge*, *laje* i *maše repom*. Prema ovom pristupu ispitanik prilikom susreta s novim entitetom doziva i pretražuje popis svojstava relevantne kategorije i testira podudarnost svojstava novog entiteta i svojstava sadržanih na popisu. Pri tome, kategorijalno učenje se definira kao nalaženje definicija ili pravila koja određuju pripadnost kategoriji. Prema ovom pristupu, jasno je određena granica pripadnosti kategoriji: pripadnost jednog entiteta jednoj kategoriji isključuje mogućnost pripadanja istog entiteta nekoj drugoj kategoriji. Svaki se entitet koji pripada kategoriji smatra podjednako dobrim predstavnikom kategorije samim time što udovoljava definiciji.

U okviru je pristupa definirajućih obilježja prvo eksperimentalno istraživanje procesa kategorijalnog učenja proveo Hull (1920). Zadatak je ispitanika u njegovu eksperimentu bio naučiti ispravno klasificirati ili imenovati prilagođene kineske znakove u različite kategorije s obzirom na jedno definirajuće obilježje koje je povezivalo sve kineske znakove koji su pripadali istoj kategoriji. No, s obzirom na to da pojmove s kojima se svakodnevno susrećemo nije jednostavno definirati vodeći se jednim definirajućim obilježjem u podlozi, Smoke (1932) proširuje Hullovo gledište (1920) i definira pojam kao složen skup obilježja povezanih nekom specifičnom vezom. Definiranje složenijih pojmova pritom se omogućuje primjenom logičkih poveznika *I*, *ILI*, *AKO* (Smith i Medin, 1981). Složene definicije u podlozi pojmova uobičajeno se nazivaju pravilima koja određuju pripadnost kategoriji. Korištenje strategija formiranja pravila ispitali su Bruner, Goodnow i Austin (1956). U svom su se istraživanju koristili karticama koje su sadržavale podražaje sastavljene od četiri dimenzije koje su mogle preuzeti tri vrijednosti (OBLIK: krug, kvadrat, križ; BOJA: crvena, zelena, crna; BROJ RUBOVA: jedan, dva, tri; BROJ OBJEKATA: jedan, dva, tri). Zadatak ispitanika bio je pogoditi pripada li prezentirani podražaj određenoj kategoriji, a svaki odgovor ispitanika slijedila je povratna informacija o točnosti. Učenje je trajalo sve do dosezanja potpuno točne klasifikacije nekoliko uzastopnih podražaja. Klasifikacijska su pravila mogla biti formirana na različite načine, no uočena su tri najčešća obrasca: pojmovi temeljeni na jednom svojstvu, pri čemu se sva ostala svojstva ignoriraju (npr. pojam čine svi crveni likovi); konjunktivni pojmovi definirani na način da posjeduju jedno svojstvo jedne dimenzije *I* drugo svojstvo druge dimenzije (npr. pojam čine crveni križevi); disjunktivni pojmovi definirani na način da posjeduju jedno svojstvo jedne dimenzije *ILI* drugo svojstvo druge dimenzije (npr. pojam čine ili crveni likovi ili križevi). Ovo i slična istraživanja (Bruner i sur., 1956; Shepard, Hovland i Jenkins, 1961) pokazala su da je uspješnost učenja pod utjecajem broja svojstava koje pravilo u podlozi kategorizacije uključuje te relacijama korištenim unutar pravila (npr. *I*, *ILI*). Uspješnost učenja dodatno je pod utjecajem kompleksnosti podražaja i redoslijeda prezentacije podražaja (Bruner i sur., 1956). Rezultati eksperimenata provedenih u

okviru pristupa definirajućih obilježja valjani su primjeri učenja kategorizacijskih pravila, no malo govore o učenju prirodnih pojmova.

### *Ograničenja pristupa definirajućih obilježja*

Ograničenja pristupa definirajućih obilježja predstavljaju kategorije za koje je nemoguće odrediti obilježja koja bi jednoznačno obuhvatila sve pripadnike kategorije. Wittgenstein još 1953. godine ističe problem definiranja pojmova kao što su *igra* ili *znanje*, a da pritom definirajućim obilježjima budu obuhvaćene karakteristike *svih igara* ili *cjelokupnog znanja*. Sljedeće ograničenje jesu kategorije čije granice nisu jasno definirane. Prilikom kategorizacije mnoge entitete nije moguće svrstati isključivo unutar jedne kategorije (Hampton, 1979). Granični pripadnici kategorija jesu oni koji dijelom sadrže svojstva jedne kategorije, a dijelom svojstva druge (npr. pripada li entitet *golf* kategoriji *SPORT* ili *IGRA*). U istraživanjima s graničnim pripadnicima pokazuje se da se ispitanici neće složiti oko pripadnosti takvog entiteta jednoj kategoriji, već će ga u podjednakoj mjeri svrstavati u dvije različite kategorije. Također, pokazuje se i da će isti ispitanik nerijetko isti entitet klasificirati različito ako ga se istom klasifikacijskom zadatku izloži s određenim vremenskim odmakom (McCloskey i Glucksberg, 1978). Nadalje, prema pristupu definirajućih obilježja, svi su pripadnici kategorije podjednako reprezentativni, no pokazuje se kako su neki članovi kategorija ipak reprezentativniji od nekih drugih (npr. pitanje reprezentativnosti entiteta *vrabac* ili *noj* za kategoriju *PTICA*). Istraživanja (Murphy i Brownell, 1985; Rips, Shoben i Smith, 1973; Rosch, 1975) pokazuju kako je klasifikacija lakša, točnija i brža za entitete koji su reprezentativniji za određenu kategoriju, zatim kako će ispitanici kao odgovor na zadanu kategoriju najprije producirati tipične pripadnike zadane kategorije, a tek onda one manje tipične (Mervis, Catlin i Rosch, 1976), kako će ispitanici prilikom kategorijalnog učenja prvo naučiti tipične pripadnike (Rosch, Simpson i Miller, 1976) te kako se neka obilježja smatraju važnijima od drugih (Rosch i Mervis, 1975). Još jedno ograničenje jest objašnjenje tranzitivnosti kategorija u okviru ovog pristupa. Prema pristupu definirajućih obilježja svaka nadređena kategorija trebala bi sadržavati sve podređene kategorije koje joj prethode (ako svi A ulaze u kategoriju B, a svi B u kategoriju C, tada i svi A ulaze u kategoriju C) (npr. *žuti labrador* ulazi u kategoriju *PAS*, koja ulazi u kategoriju *SISAVCI*), međutim pokazuje se kako načelo tranzitivnosti nije uvijek prisutno (npr. *automobilske sjedalice* ulaze u kategoriju *STOLICE*, a *stolice* u kategoriju *NAMJEŠTAJ*, no *automobilske sjedalice* ne ulaze u kategoriju *NAMJEŠTAJ*), što u okviru pristupa definirajućih obilježja nije moguće objasniti (Hampton, 1982). Svi navedeni argumenti upućuju na činjenicu da pristup definirajućih obilježja nije dovoljno fleksibilan zbog čega njime nije moguće objasniti sve relevantne aspekte kategorizacije i kategorijalnog učenja kod ljudi.

### Teorija prototipa

Polazeći od pretpostavke da je prirodne kategorije nemoguće usvojiti prema pravilima, te da one nisu precizno definirane, Rosch (1973, 1975) nastoji odgovoriti na niz ograničenja pristupa definirajućih obilježja uvođenjem teorije prototipa. Osnovne su ideje teorije da pojmovi imaju prototipsku strukturu, a da je prototip tipičan član kategorije ili prosjek članova kategorije (Rosch, 1973, 1975), odnosno kognitivna reprezentacija koja zahvaća pravilnosti i sličnosti među pripadnicima kategorije (Minda i Smith, 2011). Pri tome, kategorijalno se učenje definira kao proces stvaranja prototipa kategorije. Prilikom kategoriziranja nepoznatog entiteta, entitet se najprije uspoređuje s prototipom, a zatim se dodjeljuje kategoriji čijem prototipu najviše nalikuje.

Modeli koji objašnjavaju kategorijalno učenje u okviru teorije prototipa funkcioniraju na način da pohranjuju prosjek obilježja brojnih entiteta unutar jedne kategorije. Takav sumarni ili reprezentativni entitet može se opisati kao centralna tendencija svih pripadnika kategorije koji odražava prosjek kategorije (Reed, 1972). Istovremeno, taj prosjek ne mora biti identičan bilo kojem doživljenom entitetu. Umjesto toga, reprezentativan prototip može biti modalni entitet definiran ili kao najfrekventniji ili kao derivirani entitet koji je kombinacija najfrekventnijih obilježja. Konačno, prototip može biti *idealan* ili *žarišni* pripadnik kategorije (Rosch, 1978) koji pored toga što upućuje na sadržaj kategorije, naglašava i ona obilježja koja razlikuju kategoriju kojoj entiteti pripadaju od drugih kategorija.

U prototipskim modelima (Gluck i Bower, 1988; Hampton, 1993; Minda i Smith, 2001; Reed, 1972; Smith i Minda, 1998, 2000; Smith, Osherson, Rips i Keane, 1988), koji podrazumijevaju da svaka kategorija ima isključivo jedan prototip, novi se entitet uzima kao ulazna informacija, nakon čega se izračunava sličnost entiteta s eksplicitno specificiranim prototipima različitih kategorija i generiraju tendencije kategorijalnog odgovaranja. Ako se entitet procjenjuje sličnim kategoriji, odnosno ako prelazi svojevrсну kritičnu vrijednost ili kategorizacijski kriterij, pridodaje ga se kategoriji. Pri tome, važnu ulogu igraju obilježja kategorije koja mogu biti različito ponderirana: neka su obilježja više, a neka manje, određujuća. Nizom se istraživanja Rosch i Mervis (1975) pokazalo kako će obilježja koje dijeli većina pripadnika imati veću težinu prilikom određivanja pripada li novi entitet kategoriji. Na primjer, entitet koji je određen kao *životinja koja jede meso, ima ogrlicu i kućni je ljubimac*, potencijalno može biti klasificiran u kategoriju *PAS*. No, ako *nema izgled psa i ne laje*, odnosno, ne posjeduje obilježja koja imaju veću težinu za određivanje pripadnosti kategoriji *PAS*, klasifikacija će izostati. Prema tome, što entitet ima više obilježja koja imaju veću težinu, to je veća vjerojatnost da će biti klasificiran kao pripadnik kategorije.

Prema teoriji prototipa, kategorije posjeduju strukturu obiteljske sličnosti, reprezentirane su obilježjima koja se uobičajeno nalaze kod pripadnika kategorije, a ono što određuje pripadnost kategoriji je ima li novi entitet dovoljno

karakterističnih svojstava da bi mogao pripasti kategoriji (Rosch i Mervis, 1975). Tipičan pripadnik neke kategorije bit će onaj koji ima visoku razinu obiteljske sličnosti s ostalim pripadnicima kategorije, odnosno onaj koji ima puno preklapajućih ili zajedničkih obilježja s ostalim pripadnicima kategorije. Tipični će pripadnici dijeliti obilježja s ostalim pripadnicima kategorije, a istovremeno neće dijeliti obilježja s entitetima koji ne pripadaju kategoriji. Vrlo tipični pripadnici kategorije najviše će nalikovati prototipu, granični pripadnici tek će donekle nalikovati prototipu, a pritom će nalikovati i prototipima neke druge kategorije (Hampton, 1979; Posner i Keele, 1968, 1970; Rips i sur., 1973; Rosch i Mervis, 1975). Prema tome, neki će primjerci biti reprezentativniji pripadnici kategorije od drugih pripadnika.

Za razliku od pristupa definirajućih obilježja, teorija prototipa bez poteškoća objašnjava kategorije koje je nemoguće definirati isključivim pravilom, rješava problem graničnih pripadnika kategorije te pitanje brže kategorizacije tipičnih pripadnika kategorije u odnosu na atipične (tipični pripadnici imat će više visoko ponderiranih obilježja zbog čega će ranije dostići kategorizacijski kriterij). Također, teorija prototipa objašnjava i problem netranzitivnosti kategorija koji pristup definirajućih obilježja ne uspijeva objasniti. Ako se pozovemo na već navedeni primjer da *automobilske sjedalice* ulaze u kategoriju *STOLICE*, a *stolice* u kategoriju *NAMJEŠTAJ*, no da *automobilske sjedalice* ne ulaze u kategoriju *NAMJEŠTAJ* (Hampton, 1982), teorija prototipa objašnjava kako pojam A može biti sličan pojmu B, pri čemu pojam B može biti sličan pojmu C, a da pritom pojam A istovremeno nije dovoljno sličan pojmu C, do čega dolazi kada obilježja koja dijele pojmovi A i B nisu ista kao obilježja koja dijele pojmovi B i C (Tversky, 1977).

### *Ograničenja teorije prototipa*

Nedostatak teorije prototipa i čistih prototipskih modela jest taj da je ideja da jedan prototip može reprezentirati kategoriju u cijelosti upitna s obzirom na to da modeli ne predviđaju pohranjivanje specifičnih egzemplara, odnosno entiteta koji se u većoj mjeri razlikuju, a ipak pripadaju kategoriji. Nadalje, kategoriju je teoretski moguće reprezentirati većim brojem prototipa, osobito ako se radi o multimodalnim kategorijama ili o kategorijama čije se granice dijelom preklapaju sa susjednim kategorijama. Nedostatak teorije prototipa jest i nemogućnost objašnjavanja pojmovne kombinacije, odnosno reprezentacije prilikom formiranja složenih pojmova (npr. *školski namještaj*, *čokoladni zec*) (Hampton, 1988) s obzirom na to da složeni pojmovi nisu reprezentirani skupom osnovnih pojmova (Osherson i Smith, 1981). Još jedan nedostatak teorije prototipa jest i to da prototip ne može pružiti informaciju o razlici u varijabilitetu različitih kategorija. Naime, neke su kategorije homogenije (npr. varijacije pripadnika unutar kategorije *MAČKA* relativno su male), dok su druge puno heterogenije (npr. varijacije pripadnika unutar kategorije *PAS* vrlo su velike). Na kraju, nedostatak predstavlja i pitanje reprezentacije entiteta koji sadrže kontinuirane dimenzije (npr. je li

dimenzija *veličina ptica* reprezentirana s, primjerice, tri kategorije: *male*, *srednje*, *velike*, ili je reprezentirana kontinuirano) (Murphy, 2002).

### *Teorija egzemplara*

Ideja da jedan prototip može reprezentirati kategoriju u cijelosti odbacuje se pojavom teorije egzemplara, koju postavlja Medin i Schaffer (1978), prema kojoj se kategorija definira kao skup svih entiteta ili egzemplara pohranjenih u pamćenju, a ne kao njihov apstraktan opis (npr. prototip ili skup obilježja) (Brooks, 1987; Estes, 1986; Hintzman, 1986; Medin i Schaffer, 1978; Nosofsky, 1984). Pri tome, kategorijalno učenje se definira kao proces upamćivanja pojedinačnih egzemplara koji pripadaju kategorijama. Prilikom nailaska na nepoznati entitet, uspoređuju se sličnost tog entiteta i memorijske reprezentacije svih ranije viđenih egzemplara iz svake potencijalno relevantne kategorije, nakon čega se entitet dodjeljuje onoj kategoriji s čijim pripadnicima ima najveću prosječnu sličnost.

Modeli temeljeni na učenju egzemplara pohranjuju svaku pojavu entiteta i njegovu kategorijalnu oznaku. Kako bi se entitet klasificirao, model izračunava sličnost podražaja sa svim ostalim pohranjenim egzemplarima na osnovu podudarnosti obilježja, zatim izračunava prosječnu sličnost po kategorijama na temelju koje odlučuje o kategorizaciji (Kruschke, 2008). Kod ovakvih se modela entitet u pamćenju pohranjuje kao cjelovit egzemplar koji uključuje potpunu kombinaciju obilježja. Pri tome, svako obilježje nije pohranjeno nezavisno od drugih obilježja. Tako, kontekst jednog obilježja predstavljaju druga obilježja koja se s njime javljaju. Egzemplarne reprezentacije dopuštaju modelima zahvatiti različite aspekte ljudske kategorizacije, uključujući sposobnost učenja nelinearnih kategorijalnih distinkcija i koreliranih obilježja, istovremeno proizvodeći gradijente tipičnosti (Kruschke, 2008).

Medin i Schaffer (1978) razvijaju model konteksta (engl. *Context model*) unutar kojeg predlažu multiplikativno pravilo za izračunavanje sličnosti entiteta. Na prvom mjestu, pravilo zahtijeva identifikaciju obilježja koja povezuju dva entiteta i obilježja koja razlikuju ista dva entiteta. Nakon identifikacije obilježja potrebno je, s jedne strane, odrediti koliko su identificirana obilježja važna za određivanje sličnosti dvaju entiteta, a s druge strane, u kojoj mjeri druga obilježja razlikuju ista dva entiteta. Kako bi se izračunala sličnost dvaju entiteta, potrebno je kvantificirati važnost obilježja i razinu sličnosti prema tom obilježju. Dakle, što dva entiteta više nalikuju jedan drugome prema važnim obilježjima, a da pritom imaju čim manje obilježja prema kojima se razlikuju, veća je vjerojatnost da će biti klasificirana u istu kategoriju. U modelu konteksta, obilježja su definirana kao binarne dimenzije, pri čemu egzemplar ili posjeduje ili ne posjeduje dano obilježje.

Kako bi se u model uključile i metričke dimenzije, odnosno obilježja koja su iskazana na intervalnoj skali mjerenja poput veličine, boje i prostornog položaja, Nosofsky (1986) razvija generalizirani model konteksta (engl. *Generalized Context*

*Model, GCM*), prema kojem se klasifikacija entiteta odvija u tri koraka. Prvo, temeljna ideja modela jest da novi egzemplar s kojim se ispitanik susreće doživlja iz pamćenja druge, slične, već viđene egzemplare. Prema ovom se modelu izračunava psihološka udaljenost između egzemplara koji tek treba klasificirati i svih poznatih egzemplara unutar kategorija koje potencijalno mogu biti u vezi s novim egzemplarom. Drugo, nakon izračuna psihološke udaljenosti novog egzemplara i svih ostalih egzemplara, vrijednosti se skaliraju na način da manja udaljenost dobiva veći ponder iz razloga što odražava veću sličnost. Treće, donošenje klasifikacijske odluke temelji se upravo na usporedbi sličnosti novog egzemplara i svih ostalih egzemplara, odnosno novi će se egzemplar klasificirati u onu kategoriju s čijim ostalim pripadnicima dijeli najveću sličnost. Teorija egzemplara efekt tipičnosti objašnjava na način da su najreprezentativniji pripadnici kategorije oni koji jako nalikuju ostalim članovima kategorije, dok granične pripadnike objašnjava istovremenom podjednakom sličnosti s upamćenim pripadnicima kategorije te s upamćenim nepripadnicima kategorije. Tipični će se pripadnici klasificirati brže nego atipični iz razloga što će, zbog visoke sličnosti s ostalim pripadnicima kategorije, klasifikacijski odgovor biti ranije dostupan (Lamberts, 1995; Nosofsky i Palmeri, 1998).

Važan nedostatak modela konteksta (Medin i Schaffer, 1978) i generaliziranog modela konteksta (Nosofsky, 1986) jest izostanak specifikacije mehanizma za određivanje važnosti pojedinog obilježja prilikom izračuna sličnosti podražaja s egzemplarom. Ponder koji određuje važnost obilježja tretira se kao slobodni parametar u modelu koji se optimizira kako bi se ostvarilo najbolje poklapanje s empirijskim podacima, odnosno važnost se naknadno određuje iz opaženih rezultata. Ovaj je problem riješio Krushke (1992) postavljanjem konekcionističkog modela *ALCOVE* (engl. *Attention learning covering map*), koji, općenito, uči selektivno pristupiti dimenzijama koje su relevantne u rješavanju klasifikacijskog problema, i, istovremeno, ignorirati dimenzije koje nisu relevantne (Nosofsky, Gluck, Palmeri, McKinley i Glauthier, 1994). Važna komponenta ovog modela jest da u obzir uzima pretpostavku da selektivna pažnja može modificirati sličnosti među objektima u multidimenzionalnom prostoru (Nosofsky, 1986). Prema modelu *ALCOVE* (Krushke, 1992), asociranje egzemplara s pripadajućom kategorijom temelji se na mehanizmu učenja koji usmjerava selektivnu pažnju prema relevantnim obilježjima. Učenje se odvija putem algoritma za podešavanje pondera obilježja koji je vođen greškama. Algoritam prati razliku između svog odabira kategorije i povratne informacije o točnosti odgovora, odnosno izračunava grešku kategorizacije. Na temelju izračunate greške algoritam mijenja pondere ovisno o tome koliko su pridonijeli napravljenoj grešci. Na ovaj način model uči povezivati egzemplare s oznakama kategorija pri čemu daje različitu težinu različitim obilježjima, odnosno, implementira selektivnu pažnju prema obilježjima. Ponderi obilježja (tj. selektivna pažnja) nisu naknadno dodani u model, već su izračunati tijekom učenja kategorija. Isti je mehanizam učenja korišten i u drugim modelima kategorijalnog učenja (Gluck i Bower, 1988), a na temelju su se opisanih



modela razvile brojne modifikacije istih (npr. Kruschke i Johansen, 1999; Lee i Navarro, 2002; Verguts, Ameel i Storms, 2004). Prednost svih egzemplarnih modela jest njihova sposobnost objašnjenja usvajanja kategorija koje su slabo određene ili kategorija koje sadržavaju velike varijacije među pripadnicima (Barsalou, 1992).

### *Ograničenja teorije egzemplara*

Glavno ograničenje teorije egzemplara jest da pretpostavlja da su svi egzemplari s kojima se osoba susrela pohranjeni u pamćenju kroz jako duge vremenske periode (Murphy, 2002). Pretpostavka da se svaki prezentirani egzemplar pohranjuje u pamćenju, odnosno da se pohranjuju sve informacije o pripadnicima pojedine kategorije, pod vrlo općim uvjetima znači da bi ispitanici potencijalno trebali uvijek moći optimalno kategorizirati prezentirane entitete neovisno o kompleksnosti kategorije. Međutim, pokazuje se da često tome nije tako, iz čega proizlazi da ova teorija predviđa puno veću uspješnost kategorizacije od one koja se realno postiže (Ashby i Maddox, 2005). Na kraju, modeli koji objašnjavaju teoriju egzemplara, kategorijalno učenje uspijevaju objasniti unutar laboratorijskog konteksta, isključivo na kategorijama koje su umjetno stvorene za potrebe istraživanja (Ashby i Maddox, 2005), međutim, uzme li se obzir širi kontekst usvajanja prirodnih kategorija prilikom čega predznanje nije kontrolirano ili isključeno, tada navedeni modeli ne daju zadovoljavajuća objašnjenja (Murphy, 2002).

### **Integrativni pristup: Uloga predznanja kod kategorijalnog učenja**

Pristup koji uključuje predznanje ne može se u potpunosti klasificirati kao teorija pojmova, već se prije radi o strategiji istraživanja s ciljem utvrđivanja efekata predznanja kao odgovoru na tradicionalne eksperimente s kategorijama umjetno stvorenima upravo kako bi se utjecaj predznanja izbjegao (Murphy, 2002). Ponekad se ovaj pristup naziva samo *Teorijskim pristupom* ili *Teorijom teorije*. Različiti su autori (Heit, 1997; Murphy, 1993a, 1993b; Murphy i Medin, 1985; Schank, Collins i Hunter, 1986) sugerirali kako predznanje utječe na brzinu i točnost učenja, te kako se prilikom kategorijalnog učenja pojmovi pohranjuju kao integrativni dio općeg znanja. Znanje se koristi na aktivan način kako bi oblikovalo ono što će se naučiti te odredilo kako će se naučeno upotrebljavati nakon učenja. Predznanje se definira kao znanje o općenitim domenama koje postoje prije učenja nove kategorije, odnosno prije pristupanja eksperimentu. Ono se pritom ne odnosi na znanje o samom pojmu kojem će ispitanik biti izložen tijekom eksperimenta. Prilikom usvajanja kategorija ljudi se oslanjaju na vlastito predznanje usmjeravajući pažnju na karakteristike entiteta koje zbog utjecaja predznanja smatraju važnima, u stanju su donositi zaključke i pripisivati svojstva samom entitetu na temelju podataka koji se ne daju opaziti. Takvo znanje povezuje

svojstva novih kategorija kroz kauzalne veze i osigurava objašnjenje zašto kategorija posjeduje određena svojstva (npr. ljudi znaju kako neke životinje mogu letjeti što osigurava moguće objašnjenje zašto entitet koji ima krila može živjeti visoko na planini). Prema ovom pristupu kategorijalno učenje je pod utjecajem svojstava opaženih pripadnika kategorija i znanja o domeni kojoj bi kategorija mogla pripadati, odnosno, pod utjecajem interakcije predznanja i empirijskog učenja. Pri tome, radi se o dvosmjernoj vezi: pojmovi su pod utjecajem onoga što već znamo, ali novonaučeni pojam može modificirati opće znanje.

Utjecaj predznanja na kategorizaciju može biti indirektan i direktan. Kada je predznanje prisutno tijekom kategorijalnog učenja, ono će indirektno utjecati na prirodu reprezentacije kategorije koja se usvaja (Lin i Murphy, 1997). Lin i Murphy (1997) su pokazali da će ispitanici, ako ih se inicijalno pouči funkcijama obilježja određenih entiteta (npr. alata koji se sastoje od funkcionalno relevantnih i irelevantnih dijelova), prilikom kategorizacije sličnih modificiranih entiteta biti skloni kategorizirati vodeći se funkcionalnošću. S druge strane, predznanje može utjecati i direktno i to na način da se aktivira i rabi prilikom same kategorizacijske odluke, nakon što je period učenja završio, a moguće je i da se aktivira kad sam period kategorijalnog učenja izostane. Primjer tome jesu Barsalouva istraživanja (1983, 1985) *ad hoc* kategorija. Radi se o kategorijama koje se konstruiraju u specifičnim situacijama s ciljem opisivanja specijalizirane klase objekata koje povezuje neka zajednička svrha (npr. stvari koje treba ponijeti na kampiranje, namirnice koje ne treba jesti na dijeti). Prilikom kreiranja ovakvih vrsta kategorija, period kategorijalnog učenja u potpunosti izostaje, no sama svrha kategorije priziva značenje što omogućuje odlučivanje o tome hoće li neki entitet pripasti kategoriji ili neće.

Razvijeno je nekoliko formalnih modela koji uključuju predznanje (Heit i Bott, 2000; Heit, Briggs i Bott, 2004; Rehder, 2003), no razvoj modela u okviru ovog pristupa ograničen je iz razloga što je teško formalno specificirati sve detalje kompleksne strukture znanja. Prema konekcionističkom modelu efekata predznanja Heita i Botta (2000) obilježja entiteta reprezentiraju se kao ulazne informacije koje putem čvorova predznanja mogu biti povezane s izlaznim informacijama, odnosno, kategorijama koje treba usvojiti. Kategorije se mogu učiti direktnim asocijativnim učenjem između ulazne i izlazne informacije, ali i indirektno putem čvorova predznanja. Prema ovom modelu, obilježja koja su povezana s predznanjem usvajaju se bolje nego neutralna obilježja. Potencijalni problem ovakvog ishoda jest pretpostavka da će predznanje reducirati učenje entiteta koji nisu povezani s predznanjem, odnosno da će se učenje nekih obilježja usvajati na štetu nekih drugih.

Jedno od temeljnih pitanja koje je i danas aktualno jest razumjeti kako predznanje utječe na kategorijalno učenje iz razloga što je ono važno kod različitih aspekata korištenja kategorija. Ono može biti uključeno u definiranje svojstava objekata, može pomoći ispitanicima naučiti svojstva novih kategorija (koherentna

struktura gdje se svojstva mogu smjestiti olakšava učenje), može utjecati na vrstu odluka koje koristimo prilikom kategoriziranja nakon učenja (način na koji kategoriziramo nove objekte može biti pod djelomičnim utjecajem predznanja, prije nego isključivo pod utjecajem vlastitog iskustva s pojedinom kategorijom), i na kraju, može se koristiti kao smjernica prilikom izvođenja zaključaka o kategoriji (Murphy, 2002).

### *Ograničenja integrativnog pristupa*

Potencijalna su ograničenja ovog pristupa da se većina pojmova ne može temeljiti na predznanju te da je kod nekih pojmova potrebno prvo dobro proučiti kategorije da bi se moglo utvrditi koje je predznanje relevantno za razumijevanje kategorije. Nadalje, pristup koji u obzir uzima predznanje još uvijek nije formaliziran sveobuhvatnom teorijom koja bi mogla objasniti kategorijalno učenje i zamijeniti empirijske modele. Moguće je da istraživanja temeljena na umjetnim kategorijama barem dijelom pružaju uvid u neke mehanizme učenja u podlozi usvajanja kategorija u realnijim uvjetima u kojima nije moguće kontrolirati predznanje. Predznanje i empirijsko učenje svakako jesu u interakciji, no za sada izostaje odgovor na pitanje kako.

### **Pristupi kategorijalnom učenju zasnovani na višestrukim sustavima učenja i pamćenja**

Ranije se smatralo kako je u podlozi kategorijalnog učenja jedan sustav učenja kojim se ljudi koriste kako bi usvojili sve vrste kategorija. No, kako se u podlozi učenja obično nalaze različiti sustavi odgovorni za svladavanje različitih sadržaja, postavilo se pitanje je li kategorijalno učenje doista posredovano samo jednim sustavom učenja. Krajem prošlog i početkom ovog stoljeća istraživanja kategorijalnog učenja provedena su s ciljem otkrivanja različitih sustava kategorijalnog učenja i svojstava tih sustava. Osnovna pretpostavka u podlozi takvom pristupu jest da će pokušaj podjele funkcija u odvojenim sustavima unaprijediti razumijevanje kompleksnog fenomena kao što je kategorijalno učenje (Ashby, Paul i Maddox, 2011). Rezultati istraživanja doista upućuju na razlike u načinima na koje ljudi usvajaju kategorije ovisno o strukturi same kategorije, odnosno sugeriraju da kategorijalno učenje jest posredovano višestrukim, kvalitativno različitim sustavima (Ashby, Alfonso-Reese, Turken i Waldron, 1998; Ashby i Ell, 2001; Ashby i Maddox, 2010; Ashby i O'Brien, 2005; Ashby i Valentin, 2005; Erickson i Kruschke, 1998; Minda i Smith, 2001; Smith i Grossman, 2008; Smith i Minda, 1998). Drugim riječima, struktura kategorije određuje način učenja (Ashby i Maddox, 2005) te sustav pamćenja unutar kojeg će se kategorija pohraniti (Ashby i O'Brien, 2005). Prema teorijama kategorizacije koje se temelje na višestrukim sustavima ljudi mogu simultano rabiti veći broj

strategija učenja tijekom procesa kategorijalnog učenja. Tako, povrh testiranja hipoteza, mogu pamtit i egzemplare (Erickson i Kruschke, 1998; Nosofsky, Palmeri i McKinley, 1994) ili stvarati granice odlučivanja korištenjem višestrukih dimenzija podražaja (Ashby i sur., 1998; Ashby i Waldron, 1999).

U literaturi koja zagovara višestruke sustave kategorizacije razlikuju se eksplicitni (deklarativni, verbalni, temeljen na pravilima) i implicitni (proceduralni, neverbalni, temeljen na sličnostima) sustavi učenja. Eksplicitni sustav ili sustav testiranja hipoteza, sustav je učenja oko čijeg se postojanja različiti autori u području kategorizacije načelno slažu (Ahn i Medin, 1992; Ashby i Ell, 2001; Erickson i Kruschke, 1998; Feldman, 2000; Medin, Lynch, Coley i Atran, 1997; Nosofsky, Palmeri i sur., 1994; Regehr i Brooks, 1995; Shepard i sur., 1961). Eksplicitnim (analitičkim) sustavom kategorijalnog učenja entiteti se usvajaju korištenjem procesa usmjeravanja pažnje kojima se izdvajaju relevantna obilježja pojedinačnih entiteta. Učenje se unutar ovog sustava odvija testiranjem hipoteza o dimenzijama podražaja koje bi mogle biti relevantne problemu kategoriziranja. Pri tome, osoba se oslanja na radno pamćenje i izvršnu pažnju (testiranje i potencijalna zamjena hipoteza) (Ashby, Ell, Valentin i Casale, 2005; Minda i Miles, 2010), koristi se logičkim rezoniranjem što omogućuje svjesni pristup procesu učenja i deklarativno izvještavanje o rješenjima kategorijalnih problema koji se generiraju. Ovaj se sustav učenja temelji na eksplicitnim pravilima (Smith i sur., 2012).

Oko prirode implicitnog sustava, za koji se smatra da nije, ili barem nije u potpunosti, dostupan svijesti, još uvijek je prisutno neslaganje. Dio autora zastupa stajalište da je ovaj sustav temeljen na pohranjivanju egzemplara (Erickson i Kruschke, 1998), a dio autora zastupa stajalište da je temeljen na proceduralnom učenju (Ashby i sur., 1998; Ashby, Ell i Waldron, 2003; Ashby i Waldron, 1999). Pretpostavlja se da su oba stajališta donekle točna, a moguće je i da su u podlozi implicitnog sustava različiti podsustavi. Implicitnim (neanalitičkim) sustavom kategorijalnog učenja entiteti se usvajaju korištenjem procesa distribuirane pažnje kojima se paralelno obuhvaćaju njihova višestruka svojstva. Učenje je sporije, odvija se sporim asociranjem odgovora cjelini konfiguracije entiteta, a svjesni pristup razlozima zbog kojih se određene entitete može pripisati kategoriji izostaje. Iz navedenog slijedi da je pravila u podlozi ovakvih kategorija teško ili nemoguće verbalno opisati (Ashby i Casale, 2002; Ashby i Maddox, 2005; Minda i Miles, 2010; Smith i sur., 2012).

Ashby i njegovi suradnici (1998; Ashby i Waldron, 1999; Maddox i Ashby, 2004) postavili su model kategorijalnog učenja *COVIS* (engl. *COmpetition between Verbal and Implicit Systems*), prema kojem se u podlozi kategorijalnog učenja nalaze upravo eksplicitni i proceduralni sustavi koji su međusobno u kompeticiji za ostvarivanjem pristupa produkciji odgovora. Pri tome, eksplicitni sustav bira i testira jednostavne hipoteze o pripadnosti kategoriji koje se mogu verbalizirati, dok implicitni sustav postupno asocira kategorizacijske odgovore s regijama perceptivnog prostora. Neuroznanstvena istraživanja kategorijalnog učenja i danas

su u tijeku, a jedno od istraživačkih pitanja na koja nastoje odgovoriti jest u kakvoj su interakciji višestruki sustavi kategorijalnog učenja (Ashby i Maddox, 2010). Dostupna istraživanja sugeriraju kako su ona međusobno u kompeticiji, odnosno, kako korištenje jednog sustava istovremeno ograničava mogućnost korištenja drugog sustava (Ashby i Crossley, 2010), no takva se ograničenja mogu svladati ako ispitanici imaju dovoljan broj znakova koji signaliziraju da je za pojedine pokušaje, unutar učenja pojedine kategorije, potrebno koristiti različite sustave (Erickson, 2008). Istraživanja provedena s ciljem utvrđivanja postojanja dvaju sustava kategorijalnog učenja pokazala su da se razlike u funkcioniranju tih sustava mogu zahvatiti ispitivanjem usvajanja različitih kategorizacijskih zadataka (Ashby i Casale, 2002).

### **Metode istraživanja kategorijalnog učenja**

Kako bi se proces kategorijalnog učenja zahvatio od samog početka, u laboratorijskim se uvjetima nerijetko kategorijalno učenje proučava korištenjem nepoznatih ili umjetno stvorenih kategorija konstruiranih isključivo za potrebe istraživanja (Ashby i Maddox, 2005). Zadaci kategorijalnog učenja podrazumijevaju da ispitanik mora naučiti uspješno klasificirati podražaje koji mu se prezentiraju. Podražaji koji se prezentiraju u istraživanjima kategorijalnog učenja uobičajeno imaju nekoliko dimenzija (npr. broj, boja, veličina), a svaka dimenzija može zauzimati različite vrijednosti (npr. biti crvene ili zelene boje, biti velika ili mala) (Mayer, 1992). Pored slikovnih podražaja, koriste se i podražaji koji se sastoje od verbalnih opisa obilježja pripadnika kategorija (Murphy, 2002).

Kod istraživanja kategorijalnog učenja variraju se uvjeti prezentacije podražaja (npr. prisutnost povratne informacije, sekvencijalna ili simultana prezentacija) i priroda pravila u podlozi (Machery, 2011), a promatra se period učenja unutar kojeg sposobnost dodjeljivanja podražaja kategoriji od inicijalnog slučajnog pogađanja doseže stabilnu razinu (Ashby i Maddox, 2005). Pri tome, kod zadataka s međusobno isključivim kategorijama ispitanici mogu doseći potpunu točnost klasifikacije, dok kod zadataka s kategorijama koje se dijelom preklapaju točnost klasifikacije može doseći relativno visoku stabilnu razinu, no potpunu točnost klasifikacije nije moguće ostvariti.

#### *Zadaci kategorijalnog učenja*

##### *Zadaci temeljeni na pravilu*

Kod zadataka temeljenima na pravilu kategorije se usvajaju eksplicitnim procesima rasuđivanja, a pravilo u podlozi moguće je verbalno opisati (Ashby i Maddox, 2010; Ashby i sur., 1998). Pravilo koje određuje pripadnost kategorijama može se otkriti logičkim rezoniranjem, testiranjem hipoteza i analitičkim pristupom dimenzijama koje čine podražaje. Važna karakteristika zadataka temeljenih na

pravilu jest da preklapanje kategorija nije moguće, odnosno da je granica pripadnosti kategoriji jasna: primijenjeno pravilo razdvaja suprotstavljene kategorije i ni jedan podražaj nije prijelazan (Ashby i Maddox, 2005).

Zadaci temeljeni na pravilu koriste se još od najranijih istraživanja kategorijalnog učenja provođenima u okviru pristupa definirajućih obilježja (Bruner i sur., 1956; Hull, 1920; Smoke, 1932), a tehnike istraživanja razvijene u tom okviru upotrebljavaju se i dalje (Murphy, 2002). Shepard i sur. (1961) konstruirali su zadatke različitih razina kompleksnosti logičke strukture koja se može prikazati korištenjem geometrijskih likova čija svojstva mogu varirati na tri dimenzije: obliku (trokut/kvadrat), veličini (veliki/mali) i boji (crni/bijeli). Pokazali su kako uspješnost usvajanja zadataka ovisi o kompleksnosti pravila u podlozi kategorizacije, odnosno kako se složenost kategorijalnog učenja povećava s brojem dimenzija na koje je potrebno obratiti pažnju. Naime, kod ovakvih zadataka uobičajeno su relevantne neke dimenzije podražaja, a zadatak ispitanika je detektirati te dimenzije i mapirati njihove različite vrijednosti u različite kategorije. Pri tome, u obzir je potrebno uzeti informativne dimenzije, a neinformativne ignorirati. Zadatak kategorizacije kod kojeg je pripadnost kategoriji određena jednom dimenzijom (npr. bojom: kategoriji A pripadaju crni likovi) i kod kojeg je za davanje točnog odgovora potrebno primijeniti jednostavno pravilo pokazuje se najlakšim za usvajanje, dok se zadatak kod kojeg je pripadnost kategoriji određena dvjema dimenzijama (npr. bojom i oblikom: kategoriji A pripadaju crni trokuti i bijeli kvadrati) i kod kojeg je za davanje točnog odgovora potrebno primijeniti konjunktivno pravilo pokazuje težim. Zadatak kod kojeg je potrebno usmjeriti pažnju na sve tri dimenzije (npr. kategoriji A pripadaju svi crni likovi osim malog crnog kvadrata, a povrh toga pripada joj i mali bijeli trokut) i kod kojeg je potrebno primijeniti konjunktivno i disjunktivno pravilo predstavlja sljedeću razinu kompleksnosti kategorizacije, a zadatak čije je pravilo toliko kompleksno da je za uspješnu kategorizaciju jednostavnije pamtiiti pojedinačne pripadnike kategorije (npr. kategoriji A pripadaju veliki crni trokut i bijeli kvadrat, mali bijeli trokut i crni kvadrat), pokazuje se najtežim. Novija istraživanja (Kurtz i sur., 2013; Lafond, Lacouture i Mineau, 2007; Lewandowsky, 2011; Love i Markman, 2003) dovode u pitanje postavljeni redoslijed kompleksnosti logičkih struktura te ispituju uvjete pod kojima se isti mijenja, manipulirajući pritom varijable kao što su složenost podražaja, način prezentacije podražaja, vrsta upute i lakoća verbalnog opisa zadatka.

Kod zadataka temeljenih na pravilu nerijetko se događa da tijekom procesa učenja ispitanici formiraju pravila ili hipoteze koje su temeljene na pogrešnim dimenzijama (Mayer, 1992), i stoga, kako bi ispravno usvojili pravilo u podlozi kategorizacijskog zadatka i izbjegli ponovno testiranje pogrešnih pravila, ispitanici moraju upamtiti koje su hipoteze prilikom učenja već testirali i odbacili (Ashby i Maddox, 2010). Što se tiče kompleksnosti pravila koja mogu biti u podlozi ovakvih zadataka granica nema, no što pravilo postaje kompleksnije, to se njegova

istaknutost smanjuje na način da postaje manje vjerojatno da će ispitanik moći naučiti kategoriju eksplicitnim procesima rasuđivanja. U tom slučaju, vrlo je vjerojatno da će takav kompleksan zadatak temeljen na pravilu preći u kategoriju zadataka integracije informacija (Ashby i Maddox, 2005).

#### *Zadaci integracije informacija*

Kod zadataka integracije informacija granica u podlozi pripadnosti kategoriji nije precizna ili isključiva, što dovodi do toga da je pravilo kategorizacije teško ili nemoguće opisati riječima (Ashby i sur., 1998). Za određivanje pripadnosti kategoriji potrebno je istovremeno sagledati više dimenzija podražaja koje ispitanici moraju naučiti integrirati da bi mogli donijeti ispravnu kategorizacijsku odluku. Pri tome, pažnja mora paralelno zahvatiti više dimenzija svakog podražaja, a efikasno pridavanje podražaja kategorijama moguće je isključivo ako su informacije o dvije ili više dimenzija podražaja integrirane prije donošenja odluke (Ashby i Gott, 1988). Zadaci integracije informacija iziskuju perceptivnu integraciju koja može obuhvatiti više oblika: od izračuna diferencijalno ponderirane linearne kombinacije vrijednosti pojedinih dimenzija do tretiranja podražaja kao cjeline. Primjer takve vrste zadatka je pokazuje li skupina rendgenskih zraka tumor ili ne. Strategiju odgovaranja na ovo pitanje teško je verbalno opisati, a potrebna je ekspertnost kako bi se s određenom sigurnošću moglo postaviti dijagnozu. Pritom, optimalna kategorizacija gotovo nikad nije moguća. Prilikom usvajanja ovakve vrste zadataka aktivira se implicitni sustav kategorijalnog učenja (Ashby i Maddox, 2010), koji podrazumijeva da podražajima treba pristupiti holistički i konfiguracijski. U suprotnom, tretiranje dimenzija podražaja odvojeno ili analitički dovest će do neuspješne kategorizacije. Zbog svoje kompleksnosti, zadaci temeljeni na integraciji informacija usvajaju se značajno sporije. Moguć razlog tome je da ljudi automatski dimenzije procjenjuju odvojivima, što kod zadataka integracije informacija nije slučaj, a posljedično dovodi do usporavanja učenja (Ashby i Maddox, 2005).

#### *Istraživanja s umjetnim kategorijama: Mogućnost generalizacije*

Pored opisanih zadataka temeljenih na pravilu i zadataka integracije informacija, u literaturi se navode i drugi zadaci poput zadataka distorzije prototipa (Posner i Keele, 1968, 1970) i probabilističkih zadataka *vremenske prognoze* (Knowlton, Squire i Gluck, 1994; Meeter, Myers, Shohamy, Hopkins i Gluck, 2006). Zajedničko tim zadacima jest da podrazumijevaju učenje temeljeno na opažanju pripadnika kategorija: kategorijama se pridružuju opaženi egzemplari i njihova svojstva ili reprezentacije tih svojstava. Pri tome, koristi se podražajni materijal koji sigurno nije povezan s predznanjem ispitanika zbog artifičnosti kategorija. Istraživanja se provode podražajima kao što su geometrijski likovi (Medin i Schaffer, 1978; Shepard i sur., 1961), obrasci točaka (Posner i Keele, 1968, 1970; Smith i Minda, 2002), shematizirana lica (Nosofsky, 1991; Reed,

1972) i slično. Iako se neke od ovih podražaja može povezati sa znanjem, predznanje stečeno u svakodnevnim situacijama nema nikakvog utjecaja na proces usvajanja kategorija koje su definirane pravilom koje određuje eksperimentator. Osnovni razlog koji se navodi kao opravdanje za korištenje umjetnih kategorija jest jasna interpretabilnost rezultata. Korištenjem se umjetnih kategorija nastoji osigurati da rezultati doista odražavaju proces učenja, a ne i postojeće predznanje. Nadalje, korištenjem se jednostavnih podražaja pokušavaju zahvatiti opći principi u podlozi kategorizacije koji će se moći generalizirati na različite domene (Murphy, 2002). No, postavlja se pitanje jesu li navedeni razlozi u potpunosti opravdani. Naime, moguće je da rezultati ovakve vrste istraživanja nisu primjenjivi u realističnijim situacijama kod kojih ljudi posjeduju predznanje o domeni učenja te imaju očekivanja o pojmovima (bilo točna ili pogrešna). Također, jednostavnost principa ne znači nužno i generalizabilnost.

Ideja da predznanje može unaprijediti kategorijalno učenje u okviru je integrativnog pristupa rezultirala razvojem paradigmi koje uključuju aktivaciju predznanja s ciljem određivanja aspekata predznanja koji utječu na kategorijalno učenje.

#### *Istraživanja kategorijalnog učenja s kategorijama koje uključuju aktivaciju predznanja*

Istraživanja pokazuju da će predznanje unaprijediti kategorijalno učenje ako je smisleno ili usklađeno s kategorijom koju se uči (Wattenmaker, Devey, Murphy i Medin, 1986). Murphy i Wisniewski (1989) su ispitanicima prezentirali koherentne i nekoherentne kategorije, pri čemu su pripadnici koherentnih kategorija posjedovali svojstva koja su međusobno smisleno povezana ili barem nisu kontradiktorna (npr. *životinja: živi u vodi, jede ribu, ima mnogo potomaka, mala je*), dok su pripadnici nekoherentnih kategorija posjedovali nepovezana ili besmislena svojstva (npr. kombinirana kategorija *životinja/alat: živi u vodi, ima ravan kraj, jede pšenicu, koristi se za zidanje*). Istraživanja su pokazala da sam sadržaj kategorije određuje kompleksnost iste što znači da će znatno teže biti naučiti kategoriju ako se njezin sadržaj drastično razlikuje od ispitanikova predznanja, odnosno logički ne odgovara predznanju kao kod nekoherentnih kategorija. S druge strane, koherentne se kategorije uče brže, s manje grešaka i s većom sigurnošću u točnost odgovora (Murphy i Wisniewski, 1989; Wattenmaker i sur., 1986). Slično tome, rezultati istraživanja koje su proveli Murphy i Allopena (1994) pokazali su kako se tematski povezane kategorije usvajaju brže u odnosu na neutralne, što upućuje na to da je učenje lakše kada je predznanje konzistentno s kategorijom koju treba usvojiti nego kada je nekonzistentno ili ga nema. Jedno objašnjenje efekata znanja koje navode jest da predznanje usmjerava pažnju ispitanika na relevantna svojstva, dok kao drugo objašnjenje navode mogućnost da ono što je već pohranjeno, a aktivira se predznanjem, ne treba biti ponovno naučeno, zbog čega dolazi do svojevrsne vremenske uštede prilikom učenja novokonstruirane kategorije. S obzirom na to da učenje uključuje interakciju onoga



što je već pohranjeno i onoga što tek treba biti pohranjeno, može se reći da predznanje pospješuje učenje novih karakteristika.

Kaplan i Murphy (2000) su ispitali kako količina i dosljednost znanja utječu na kategorijalno učenje. Ispitanicima su prezentirali kategorije sastavljene od pripadnika koji su posjedovali većinu neutralnih obilježja i tek jedno tematsko za koje se pretpostavilo da će aktivirati predznanje. Očekivali su kako će učenje kategorija nastupiti tek kada ispitanik zaključi kako tematska obilježja različitih pripadnika kategorije povezuju cjelinu, odnosno pripadnike kategorije međusobno. Rezultati istraživanja su pokazali da su ispitanici značajno brže usvajali kategorije kada su tematska obilježja bila prisutna, što upućuje na zaključak da predznanje unaprijeđuje učenje čak i kad nije u potpunosti konzistentno ili povezano s većinom ostalih obilježja pripadnika kategorije. Također, pokazalo se i kako se kategorije kod kojih je aktivirano kontradiktorno predznanje usvajaju jednakom brzinom kao kategorije u uvjetu u kojem se predznanje ne aktivira, iako bi se očekivalo da će kontradiktorno predznanje dodatno usporiti učenje. Ovaj je nalaz za sada još uvijek nedovoljno istražen, no pretpostavlja se da ispitanici ignoriraju *pogrešno znanje* čim ustanove da im ne može koristiti. Dakle, iako je predznanje načelno korisno, uočavanjem internalnih nekonzistentnosti moguća je identifikacija situacija u kojima neće biti od koristi.

Na kraju, rezultati istraživanja koje je proveo Pazzani (1991) pokazali su kako na proces usvajanja kategorija utječu i očekivanja ispitanika na način da pospješuju učenje ako su povezana sa sadržajem kategorije koju se uči, i na taj način aktiviraju predznanje. Povrh toga, pokazalo se i da su ispitanici u uvjetu koji je aktivirao očekivanja brže usvojili kategoriju u čijoj je podlozi disjunktivno pravilo, a sporije onu u čijoj je podlozi konjunktivno pravilo, što je suprotno nalazima ranijih istraživanja da se složenije kategorije usvajaju sporije (Bruner i sur., 1956; Medin i Schaffer, 1978; Shepard i sur., 1961). Iz navedenoga slijedi da se prednost konjunktivnih pravila može izgubiti uvođenjem faktora očekivanja koji aktivira predznanje, a potencijalno se dovodi u pitanje mogućnost generalizacije rezultata istraživanja dobivenih na umjetnim kategorijama na realnije životne situacije kategorijalnog učenja.

## **Zaključak**

Navedeni pristupi kategorijalnom učenju zahvaćaju različite aspekte procesa u podlozi ovoga kompleksnoga kognitivnog fenomena, no neovisno o dugoj istraživačkoj tradiciji, sveobuhvatno objašnjenje kategorijalnog učenja i dalje izostaje. Velik je problem dosadašnjih istraživanja što su teorije građene na osnovu specifičnih podražaja korištenih u istraživanjima, te vrlo često nije moguće generalizirati dobivene rezultate na situacije izvan korištenih eksperimentalnih paradigmi. Većina teorija promatra ispitanika kao pasivnog primaoca informacija

koji se koristi samo jednom vrstom reprezentacije znanja, dok u realnim situacijama ispitanici vjerojatno primjenjuju strategije koje se oslanjaju na različite reprezentacijske formate kako bi uspješno riješili postavljeni zadatak. Teorije egzemplara i prototipa u potpunosti zanemaruju predznanje i nije jasno na koji bi način one mogle objasniti utjecaj predznanja te ostalih faktora, poput očekivanja i konteksta učenja na kategorizaciju. S druge strane, integrativni pristup koji uključuje predznanje ne uspijeva objasniti proces usvajanja artificalnih kategorija čije se usvajanje temelji isključivo na empirijskom učenju.

Iz pregleda literature proizlazi da su kategorije sastavljene od višestrukih reprezentacija koje se različito aktiviraju ovisno o kontekstu. Raznolikost u mogućim reprezentacijama kategorija otežava konstrukciju teorija i modela kategorijalnog učenja i kategorizacije (Barsalou, 1992). Iz navedenih razloga opravdano je reći da je svaka teorija pojmova djelomično u pravu jer zahvaća određeni aspekt kategorizacije, no i ostavlja mnogo prostora za druga objašnjenja. Ljudi su sposobni pamti egzemplare, stvarati prototipe, usvajati pravila, testirati i retestirati hipoteze, koristiti se znanjima o određenoj domeni te povezivati različite informacije koje potencijalno mogu opisati kategoriju u različitim situacijama kategorijalnog učenja. Istraživanja sugeriraju da proces učenja ovisi o strukturi kategorija koje se uče (odnosno o broju prezentiranih entiteta, o sličnosti među entitetima, o razlikama među prezentiranim kategorijama) i o stadiju kategorijalnog učenja (Minda i Smith, 2001; Nosofsky, 2000; Nosofsky i Zaki, 2002; Smith, 2002; Smith i Minda, 1998, 2000; Zaki i Nosofsky, 2007), te da je, prema tome, moguće odabrati širok raspon različitih strategija prilikom usvajanja kategorija. Iz navedenoga proizlazi da je nužno osmisliti nove pravce u istraživanju kategorijalnog učenja povezivanjem s teorijama i metodama drugih područja kognitivne psihologije, kao što su istraživanja pamćenja, metakognicije i kognitivne neuroznanosti, kako bi se došlo do preciznije slike koji se sustav učenja i pamćenja aktivira u pojedinom zadatku kategorizacije. Modeli poput COVIS-a (Ashby i sur., 1998; Ashby i Waldron, 1999; Maddox i Ashby, 2004) prvi su korak u tom smjeru.

## Literatura

- Ahn, W. i Medin, D.L. (1992). A two-stage model of category construction. *Cognitive Science*, 16, 81-121.
- Ashby, F.G., Alfonso-Reese, L.A., Turken, A.U. i Waldron, E.M. (1998). A neuropsychological theory of multiple systems in category learning. *Psychological Review*, 105, 442-481.
- Ashby, F.G. i Casale, M.B. (2002). The cognitive neuroscience of implicit category learning. U: L. Jiménez (Ur.), *Attention and implicit learning* (str. 109-141). Amsterdam & Philadelphia: John Benjamins Publishing Company.

- Ashby, F.G. i Crossley, M.J. (2010). Interactions between declarative and procedural-learning categorization systems. *Neurobiology of Learning and Memory*, 94, 1-12.
- Ashby, F.G. i Ell, S.W. (2001). The neurobiology of human category learning. *Trends in Cognitive Sciences*, 5, 204-210.
- Ashby, F.G., Ell, S.W., Valentin, V. i Casale, M.B. (2005) FROST: A distributed neurocomputational model of working memory maintenance. *Journal of Cognitive Neuroscience*, 17, 1728-1743.
- Ashby, F.G., Ell, S.W. i Waldron, E.M. (2003). Procedural learning in perceptual categorization. *Memory & Cognition*, 31, 1114-1125.
- Ashby, F.G. i Gott, R.E. (1988). Decision rules in the perception and categorization of multidimensional stimuli. *Journal of Experimental Psychology: Learning, Memory and Cognition*, 14(1), 33-53.
- Ashby, F.G. i Maddox, W.T. (2005). Human category learning. *Annual Review of Psychology*, 56, 149-178.
- Ashby, F.G. i Maddox, W.T. (2010). Human category learning 2.0. *Annals of the New York Academy of Sciences*, 1224, 147-161.
- Ashby, F.G. i O'Brien, J.B. (2005). Category learning and multiple memory systems. *Trends in Cognitive Science*, 2, 83-89.
- Ashby, F.G., Paul, E.J. i Maddox, W.T. (2011). COVIS. U: E.M. Pothos i A.J. Wills (Ur.), *Formal approaches in categorization* (str. 65-87). New York: Cambridge University Press.
- Ashby, F.G. i Valentin, V.V. (2005). Multiple systems of perceptual category learning: Theory and cognitive tests. U: H. Cohen i C. Lefebvre (Ur.), *Handbook of categorization in cognitive science* (str. 547-572). Amsterdam: Elsevier.
- Ashby, F.G. i Waldron, E.M. (1999). The nature of implicit categorization. *Psychonomic Bulletin & Review*, 6, 363-378.
- Barsalou, L.W. (1983). Ad hoc categories. *Memory & Cognition*, 11, 211-227.
- Barsalou, L.W. (1985). Ideals, central tendency, and frequency of instantiation as determinants of graded structure in categories. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 11, 629-654.
- Barsalou, L.W. (1992). *Cognitive psychology: An overview for cognitive scientists*. Hillsdale, NJ: Lawrence Erlbaum Associates.
- Brooks, L.R. (1987). Decentralized control of categorization: The role of prior processing episodes. U: U. Neisser (Ur.), *Concepts and conceptual development: Ecological and intellectual factors in categorization* (str. 141-174). Cambridge: Cambridge University Press.
- Bruner, J.S., Goodnow, J.J. i Austin, G.A. (1956). *A study of thinking*. New York: John Wiley.

- Erickson, M.A. (2008). Executive attention and task switching in category learning: Evidence for stimulus-dependent representation. *Memory & Cognition*, 36, 749-761.
- Erickson, M.A. i Kruschke, J.K. (1998). Rules and exemplars in category learning. *Journal of Experimental Psychology: General*, 127, 107-140.
- Estes, W.K. (1986). Memory storage and retrieval processes in category learning. *Journal of Experimental Psychology: General*, 115(2), 155-174.
- Feldman, J. (2000). Minimization of Boolean complexity in human concept learning. *Nature*, 407, 630-633.
- Gluck, M.A. i Bower, G.H. (1988). From conditioning to category learning: An adaptive network model. *Journal of Experimental Psychology: General*, 117(3), 227-247.
- Gluck, M.A., Shohamy, D. i Myers, C. (2002). How do people solve the "weather prediction" task?: Individual variability in strategies for probabilistic category learning. *Learning & Memory*, 9, 408-418.
- Hampton, J.A. (1979). Polymorphous concepts in semantic memory. *Journal of Verbal Learning and Verbal Behavior*, 18, 441-461.
- Hampton, J.A. (1982). A demonstration of intransitivity in natural categories. *Cognition*, 12, 151-164.
- Hampton, J.A. (1988). Overextension of conjunctive concepts: Evidence for a unitary model of concept typicality and class inclusion. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 14, 12-32.
- Hampton, J.A. (1993). Prototype models of concept representation. U: I. Van Mechelen, J. Hampton, R.S. Michalski i P. Theuns (Ur.), *Categories and concepts: Theoretical views and inductive data analysis* (str. 67-95). London: Academic Press.
- Heit, E. (1997). Knowledge and concept learning. U: K. Lamberts i D. Shanks (Ur.), *Knowledge, concepts, and categories* (str. 7-41). Hove, England: Psychology Press.
- Heit, E. i Bott, L. (2000). Knowledge selection in category learning. U: D.L. Medin (Ur.), *The psychology of learning and motivation* (str. 163-199). San Diego: Academic Press.
- Heit, E., Briggs, J. i Bott, L. (2004). Modeling the effects of prior knowledge on learning incongruent features of category members. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 30, 1065-1081.
- Hintzman, D.L. (1986). "Schema abstraction" in a multiple-trace memory model. *Psychological Review*, 93, 411-428.
- Hull, C.L. (1920). Quantitative aspects of the evolution of concepts. *Psychological Monographs*, XXVIII (1.123), 1-86.
- Kaplan, A.S. i Murphy, G.L. (2000). Category learning with minimal prior knowledge. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 26, 829-846.
- Knowlton, B.J., Squire, L.R. i Gluck, M.A. (1994). Probabilistic classification learning in amnesia. *Learning & Memory*, 1, 106-120.

- Kruschke, J.K. (1992). ALCOVE: An exemplar-based connectionist model of category learning. *Psychological Review*, 99(1), 22-44.
- Kruschke, J.K. (2008). Models of categorization. U: R. Sun (Ur.), *The Cambridge handbook of computational psychology* (str. 267-301). New York: Cambridge University Press.
- Kruschke, J.K. i Johansen, M.K. (1999). A model of probabilistic category learning. *Journal of Experimental Psychology: Learning, Memory and Cognition*, 25, 1083-1119.
- Kurtz, K.J., Levering, K.R., Stanton, R.D., Romero, J. i Morris, S.N. (2013). Human learning of elemental category structures: Revising the classic result of Shepard, Hovland, and Jenkins (1961). *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 39(2), 552-572.
- Lafond, D., Lacouture, Y. i Mineau, G. (2007). Complexity minimization in rule-based category learning: Revising the catalog of Boolean concepts and evidence for non-minimal rules. *Journal of Mathematical Psychology*, 51, 57-74.
- Lamberts, K. (1995). Categorization under time pressure. *Journal of Experimental Psychology: General*, 124, 161-180.
- Lee, M.D. i Navarro, D.J. (2002). Extending the ALCOVE model of category learning to featural stimulus domains. *Psychonomic Bulletin & Review*, 9, 43-58.
- Lewandowsky, S. (2011). Working memory capacity and categorization: Individual differences and models. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 37, 720-738.
- Lin, E.L. i Murphy, G.L. (1997). The effects of background knowledge on object categorization and part detection. *Journal of Experimental Psychology: Human Perception and Performance*, 23, 1153-1169.
- Love, B.C. i Markman, A.B. (2003). The nonindependence of stimulus properties in human category learning. *Memory & Cognition*, 31, 790-799.
- Machery, E. (2011). Concepts: A tutorial. U: R. Belohlavek i G.J. Klir (Ur.), *Concepts and fuzzy logic* (str. 13-44). Cambridge, MA: MIT Press.
- Maddox, W.T. i Ashby, F.G. (2004). Dissociating explicit and procedural-learning based systems of perceptual category learning. *Behavioural Processes*, 66, 309-332.
- Mayer, R.E. (1992). *Thinking, problem solving, cognition* (2<sup>nd</sup> edition). New York: W.H. Freeman and Company.
- McCloskey, M. i Glucksberg, S. (1978). Natural categories: Well-defined or fuzzy sets? *Memory and Cognition*, 6, 462-472.
- Medin, D.L., Lynch, E.B., Coley, J.D. i Atran S. (1997). Categorization and reasoning among tree experts: Do all roads lead to Rome? *Cognitive Psychology*, 32, 49-96.

- Medin, D.L. i Rips, L.J. (2005). Concepts and categories: Memory, meaning, and metaphysics. U: K.J. Holyoak i R.G. Morrison (Ur.), *The Cambridge handbook of thinking and reasoning* (str. 37-72). New York, US: Cambridge University Press.
- Medin, D.L. i Schaffer, M.M. (1978). Context theory of classification learning. *Psychological Review*, 85, 207-238.
- Meeter, M., Myers, C., Shohamy, D., Hopkins, R. i Gluck, M. (2006). Strategies in probabilistic categorization: Results from a new way of analyzing performance. *Learning and Memory*, 13, 230-239.
- Mervis, C.B., Catlin, J. i Rosch, E. (1976). Relationships among goodness-of-example, category norms, and word frequency. *Bulletin of the Psychonomic Society*, 7, 283-284.
- Minda, J.P. i Miles, S.J. (2010). The influence of verbal and nonverbal processing on category learning. U: B.H. Ross (Ur.), *The psychology of learning and motivation* (Vol. 52, str. 117-162). Burlington: Academic Press.
- Minda, J.P. i Smith, J.D. (2001). Prototypes in category learning: The effects of category size, category structure, and stimulus complexity. *Journal of Experimental Psychology: Learning, Memory, & Cognition*, 27, 775-799.
- Minda, J.P. i Smith, J.D. (2011). Prototype models of categorization: Basic formulation, predictions, and limitations. U: E. Pothos i A. Wills (Ur.), *Formal approaches in categorization* (str. 40-64). Cambridge University Press: Cambridge, UK.
- Murphy, G.L. (1993a). A rational theory of concepts. U: G.V. Nakamura, R.M. Taraban i D.L. Medin (Ur.), *The psychology of learning and motivation: Categorization by humans and machines* (str. 327-359). New York: Academic Press.
- Murphy, G.L. (1993b). Theories and concept formation. U: I. Van Mechelen, J. Hampton, R. Michalski i P. Theuns (Ur.), *Categories and concepts: Theoretical views and inductive data analysis* (str. 173-200). New York: Academic Press.
- Murphy, G.L. (2002). *The big book of concepts*. Cambridge, MA: Mit Press.
- Murphy, G.L. i Allopenna, P.D. (1994). The locus of knowledge effects in concept learning. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 20, 904-919.
- Murphy, G.L. i Brownell, H.H. (1985). Category differentiation in object recognition: Typicality constraints on the basic category advantage. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 11, 70-84.
- Murphy, G.L. i Medin, D.L. (1985). The role of theories in conceptual coherence. *Psychological Review*, 92, 289-316.
- Murphy, G.L. i Wisniewski, E.J. (1989). Feature correlations in conceptual representations. U: G. Tiberghien (Ur.), *Advances in cognitive science, Vol. 2: Theory and applications* (str. 23-45). Chichester: Ellis Horwood.
- Nosofsky, R.M. (1984). Choice, similarity, and the context theory of classification. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 10(1), 104-114.

- Nosofsky, R.M. (1986). Attention, similarity, and the identification-categorization relationship. *Journal of Experimental Psychology: General*, 115(1), 39-57.
- Nosofsky, R.M. (1991). Tests of an exemplar model for relating perceptual classification and recognition memory. *Journal of Experimental Psychology: Human Perception & Performance*, 17(1), 3-27.
- Nosofsky, R.M. (2000). Exemplar representation without generalization? Comment on Smith and Minda's (2000) "Thirty categorization results in search of a model". *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 26(6), 1735-1743.
- Nosofsky, R.M., Gluck, M.A., Palmeri, T.J., McKinley, S.C. i Glauthier, P. (1994). Comparing models of rule-based classification learning: A replication and extension of Shepard, Hovland, and Jenkins (1961). *Memory & Cognition*, 22(3), 352-369.
- Nosofsky, R.M. i Palmeri, T.J. (1998). A rule-plus-exception model for classifying objects in continuous-dimension spaces. *Psychonomic Bulletin & Review*, 5(3), 345-369.
- Nosofsky, R.M., Palmeri, T.J. i McKinley, S.C. (1994). Rule-plus-exception model of classification learning. *Psychological Review*, 101(1), 53-79.
- Nosofsky, R.M. i Zaki, S.R. (2002). Exemplar and prototype models revisited: Response strategies, selective attention, and stimulus generalization. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 28(5), 924-940.
- Osherson, D.N. i Smith E.E. (1981). On the adequacy of prototype theory as a theory of concepts. *Cognition*, 9(1), 35-58.
- Pazzani, M. (1991). The influence of prior knowledge on concept acquisition: Experimental and computational results. *Journal of Experimental Psychology: Learning, Memory & Cognition*, 17(3), 416-432.
- Posner, M.I. i Keele, S.W. (1968). On the genesis of abstract ideas. *Journal of Experimental Psychology*, 77, 353-363.
- Posner, M.I. i Keele, S.W. (1970). Retention of abstract ideas. *Journal of Experimental Psychology*, 83, 304-308.
- Reed, S.K. (1972). Pattern recognition and categorization. *Cognitive Psychology*, 3, 383-407.
- Regehr, G. i Brooks, L.R. (1995). Category organization in free classification: The organizing effect of an array of stimuli. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 21, 347-363.
- Rehder, B. (2003). A causal-model theory of conceptual representation and categorization. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 29(6), 1141-1159.
- Rips, L., Shoben, E. i Smith, E. (1973). Semantic distance and the verification of semantic relations. *Journal of Verbal Learning and Verbal Behavior*, 12, 1-20.

- Rosch, E. (1973). On the internal structure of perceptual and semantic categories. U: T.E. Moore (Ur.), *Cognitive development and the acquisition of language* (str. 111-144). Oxford, England: Academic Press.
- Rosch, E. (1975). Cognitive representations of semantic categories. *Journal of Experimental Psychology: General*, 104, 192-233.
- Rosch, E. (1978). Principles of categorization. U: E. Rosch i B.B. Lloyd (Ur.), *Cognition and categorization* (str. 28-48). Hillsdale, NJ: Erlbaum.
- Rosch, E. i Mervis, C.B. (1975). Family resemblances: Studies in the internal structure of categories. *Cognitive Psychology*, 7(4), 573-605.
- Rosch, E., Simpson, C. i Miller, R.S. (1976). Structural bases of typicality effects. *Journal of Experimental Psychology: Human Perception and Performance*, 2, 491-502.
- Schank, R., Collins, G. i Hunter, L. (1986). Transcending inductive category formation in learning. *Behavioral and Brain Sciences*, 9, 639-686.
- Shepard, R.N., Hovland, C. i Jenkins H.M. (1961). Learning and memorization of classifications. *Psychological Monographs: General and Applied*, 75(13), 1-41.
- Smith, E.E. (1993). Concepts and induction. U: M.I. Posner (Ur.), *Foundations of cognitive science* (str. 501-526). Cambridge, MA: MIT Press.
- Smith, E.E. i Grossman, M. (2008). Multiple systems of category learning. *Neuroscience and Biobehavioral Reviews*, 32, 249-264.
- Smith, E.E. i Medin, D.L. (1981). *Categories and concepts*. Cambridge, MA: Harvard University Press.
- Smith, E.E., Osherson, D.N., Rips, L.J. i Keane, M. (1988). Combining prototypes: A selective modification model. *Cognitive Science*, 12(4), 485-527.
- Smith, J.D. (2002). Exemplar theory's predicted typicality gradient can be tested and disconfirmed. *Psychological Science*, 13, 437-442.
- Smith, J.D., Berg, M.E., Cook, R.G., Murphy, M.S., Crossley, M.J., Boomer, J., ... Grace, R.C. (2012). Implicit and explicit categorization: A tale of four species. *Neuroscience and Biobehavioral Reviews*, 36(10), 2355-2369.
- Smith, J.D. i Minda, J.P. (1998). Prototypes in the mist: The early epochs of category learning. *Journal of Experimental Psychology: Learning, Memory, & Cognition*, 24, 1411-1436.
- Smith, J.D. i Minda, J.P. (2000). Thirty categorization results in search of a model. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 26(1), 3-27.
- Smith, J.D. i Minda, J.P. (2002). Distinguishing prototype-based and exemplar-based processes in dot-pattern category learning. *Journal of Experimental Psychology: Learning, Memory, & Cognition*, 28, 800-811.
- Smoke, K.L. (1932). An objective study of concept formation. *Psychological Monographs*, XLII (191), 1-46.



- Tversky, A. (1977). Features of similarity. *Psychological Review*, 84, 327-352.
- Verguts, T., Ameel, E. i Storms, G. (2004). Measures of similarity in models of categorization. *Memory & Cognition*, 32, 379-389.
- Wattenmaker, W.D., Devey, G.I., Murphy, T.D. i Medin, D.L. (1986). Linear separability and concept learning: Context, relational properties, and concept naturalness. *Cognitive Psychology*, 18, 158-194.
- Wittgenstein, L. (1953). *Philosophical investigations*. Oxford: Basil Blackwell.
- Zaki, S.R. i Nosofsky, R.M. (2007). A high-distortion enhancement effect in the prototype-learning paradigm: Dramatic effects of category learning during test. *Memory & Cognition*, 35, 2088-2096.

## Theoretical and Methodological Approaches to Category Learning

---

### Abstract

Numerous studies have attempted to determine the process of acquiring knowledge which is represented in categories, and different approaches to categorization and category learning were proposed. This paper presents an overview of approaches to category learning. According to the Classical view or the Definitional approach, category learning is a process of finding definitions or rules that uniquely define category membership. The Prototype theory describes category learning as a process of creating a category prototype which reflects the average features of all category members, which can be a summary representation or the most representative category member. According to the Exemplar view, category learning is equal to memorizing or storing individual exemplars or category members in long-term memory. Contrary to the listed approaches, the Integrative approach assumes that category learning is influenced by broader knowledge which is inevitably activated when encountering entities that need to be properly classified. Today, research on category learning indicates that category learning cannot be explained by a single memory system, but that it is mediated by multiple, qualitatively different memory systems. Special attention is paid to the distinction between the explicit or declarative, and the implicit or procedural system, since research shows that activation of the specific memory system depends on the type of category learning task which has to be mastered.

**Keywords:** category learning, prototypes, exemplars, knowledge, multiple category learning systems

---

Primljeno: 18.05.2014.

